

Método para Extração de Características de Dados em Séries Temporais para Detecção de Falhas em Sistemas Complexos

Dennys Wallace Duncan Imbassahy, Henrique Costa Marques e Guilherme Conceição Rocha
 Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos/SP – Brasil

Resumo – Os principais métodos para detecção e isolamento de falhas dependem ou de um modelo de previsão bem aproximado da realidade ou de um conjunto de dados que represente adequadamente todas as falhas que se deseja detectar. Quando isso não ocorre, eles podem apresentar taxas de erros não aceitáveis. Este trabalho apresenta um método baseado no modelo dos sinais denominado Matriz de Zeros que permite a detecção através da extração do perfil característico da falha monitorada. Essa matriz permite ainda a percepção de falhas incipientes uma vez que não se baseia em limiares. Seu principal benefício é não depender de um modelo robusto do sistema e nem de um conjunto de dados que represente bem todas as falhas.

Palavras-Chave – FDI, detecção e isolamento de falhas, processamento de falha baseado em sinal.

I. INTRODUÇÃO

O processo de detecção e isolamento de falhas (FDI – *Fault Detection and Isolation*) é fundamental para o funcionamento de diversos sistemas, seja ele físico como uma aeronave ou virtual como um firewall de uma rede de computadores. Tal processo é atualmente construído/orientado sob três paradigmas mais comuns: de dados - *Data-Driven* (DD), do modelo - *Model-Based* (MB) ou de uma combinação de ambos, denominado híbrido.

O sucesso da implementação de métodos DD dependem principalmente da qualidade dos conjuntos de dados utilizados em representar os diversos modos de falhas que se pretende identificar e isolar. Contudo, conforme observado em [1], mesmo quando o conjunto é bem vasto em quantidade de dados, ele pode não representar todo o domínio de falhas possíveis visto que determinados conjuntos de falhas raras podem não estar presentes nos dados disponíveis. No entanto, tal método torna-se a opção mais comum se não houver um modelo que represente o sistema.

Quando se possui o conhecimento do sistema, a partir do seu funcionamento e saídas esperadas é possível desenvolver o modelo e realizar comparações. Há quatro abordagens principais baseadas em modelos segundo [2]:

1. Redundância de hardware, com alto custo e utilizada em sistemas importantes em que a diferença na saída dos dois sistemas reais informa diretamente o sistema em pane;
2. Testes de plausibilidade, que compara leis físicas às saídas do sistema. Quando não há uma explicação plausível sobre o sinal de saída então há a detecção da falha;
3. Esquemas de redundância de software/analíticos, que fazem uso de modelagem matemática para reproduzir o sistema em monitoramento, partindo então para uma comparação da saída do sinal real ao sinal modelado,

semelhante à redundância de hardware. A diferença entre as medições, chamada de resíduo, indicará se ocorreu falha sempre que tal diferença for diferente de um determinado limiar próximo de zero; e

4. Processamento de sinais, quando os sinais de saída possuem características das falhas geradas e podem ser analisados como sintomas, durante o processamento do sinal.

A abordagem baseada em esquemas de redundância de software/analíticos permite a seleção de resíduos e é a mais amplamente utilizada nos trabalhos com abordagem MB devido a seus bons resultados. Porém, desenvolver um modelo como esse não é trivial e tão comum e, mesmo quando é possível obtê-lo, a seleção das equações e variáveis mais adequadas para detecção da falha é tema de estudos dada a sua complexidade [3].

As abordagens híbridas procuram minimizar essas fraquezas combinando métodos MB e DD [4]. Ainda assim, diante dessa situação, faz-se necessário a percepção de como os métodos selecionados para cada abordagem se comportam isoladamente diante desse cenário antes de tentar combiná-los.

Este trabalho desenvolveu um método MB usando a abordagem *Templates* [5], baseada em processamento de sinais, utilizando os padrões de formato aparente de sinais medidos em sensores após a ocorrência de falhas de diferentes naturezas. A Fig. 1 demonstra os 3 perfis a serem identificados.

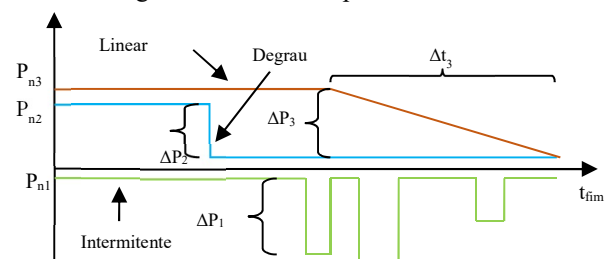


Fig. 1. Perfis do sinal na ocorrência das falhas.

Os padrões, ou perfis do formato aparente de sinais após falhas, são: o Intermittente, caracterizado por variações abruptas de alta amplitude ΔP_1 do parâmetro P_{n1} , retornando à condição original de normalidade P_{n1} ; o Linear, ou Incipiente que é caracterizado por ΔP_3 e Δt_3 sendo a derivação progressiva e lenta do valor do parâmetro P_{n3} (degradação, após evento de falha incipiente); e o Degrau que é caracterizado por ΔP_2 que é uma alteração abrupta, persistente e de alta intensidade do valor do parâmetro P_{n2} .

Nesse contexto, o objetivo do presente trabalho é desenvolver uma abordagem MB baseada em processamento de sinais e compará-la com uma abordagem baseada em dados, a partir de um breve estudo de caso, permitindo identificar suas vantagens e desvantagens na situação específica. Tais abordagens são comparadas quanto ao desempenho em extrair

corretamente as características dos sinais adquiridos de sensores. Tal comparação só foi possível pois as duas técnicas utilizadas fazem uso dos sinais de saída para identificarem o comportamento do sinal em tempo de processamento.

O artigo foi organizado da seguinte forma: a Seção II explica o método MB desenvolvido. Na Seção III, é feito um estudo de caso com um conjunto de dados obtidos de uma competição de algoritmos para FDI. Os resultados são então analisados e divulgados na Seção IV. Por último, a seção V finaliza com as principais conclusões e propostas para trabalhos futuros.

II. MÉTODO

O método desenvolvido para extração de características do sinal e subsequente detecção e isolamento de falhas, chamado de “Matriz de Zeros”, seguiu uma abordagem com foco no perfil de sinal emitido traduzido para um modelo matricial onde é feita sua interpretação e não depende de um conjunto de dados para seu treinamento, mas sim de uns poucos que permitam a compreensão de sua estrutura e abstrações de regras gerais.

A primeira etapa consiste na suavização do sinal. Todo o processo utilizado segue a sequência de equações de (1) até (5). Para um conjunto de dados C conforme (1) ordenados no domínio do tempo, é obtida a matriz M em (2) com a quantidade de linhas igual a quantidade de elementos de (1) e duas colunas: a primeira para armazenar os valores em ordem crescente e a segunda com seus respectivos índices no conjunto de origem.

$$C = \{p_1, p_2, \dots, p_n \mid p \in \mathbb{R} \text{ e } n \in \mathbb{N}^*\} \quad (1)$$

$$M = \begin{bmatrix} v_k & k \\ \vdots & \vdots \\ v_j & j \end{bmatrix}, v_k \leq \dots \leq v_j, k \neq j, 1 \leq k \leq n \text{ e } 1 \leq j \leq n \quad (2)$$

Cada linha de (2) obtém um subconjunto definido em (3), $Q_k \subset C$, com os valores ordenados crescentemente.

$$Q_x = \begin{cases} C[p_{x-i}, \dots, p_{x+i}], & k - i \geq 1 \text{ e } k + i \leq n \\ C[p_1, \dots, p_{1+2i}], & k - i < 1 \\ C[p_{n-2i}, \dots, p_n], & k + i > n \end{cases} \quad (3)$$

Sendo o valor de x dado pela segunda coluna de cada linha da matriz e i como a metade da largura da janela desejada dos subconjuntos dos quais serão extraídas as medianas em relação a x . Cada linha tem o valor da primeira coluna atualizado com o valor obtido em (4).

$$v(x) = \{p_i \mid p_i \in Q_x \text{ e } i = \frac{|Q_x|}{2}\} \quad (4)$$

O sinal suavizado é obtido reordenando as linhas de (2) em relação a ordem crescente da segunda coluna e obtendo os valores da primeira coluna conforme em (5).

$$S = \{v_{1,1}, v_{2,1}, \dots, v_{n,1}\} \quad (5)$$

A suavização feita dessa forma permite reduzir a interferência de ruídos e ao mesmo tempo não afeta significativamente a característica do formato do sinal, o que torna mais provável a extração de características corretas em sinais que apresentem falhas ainda incipientes.

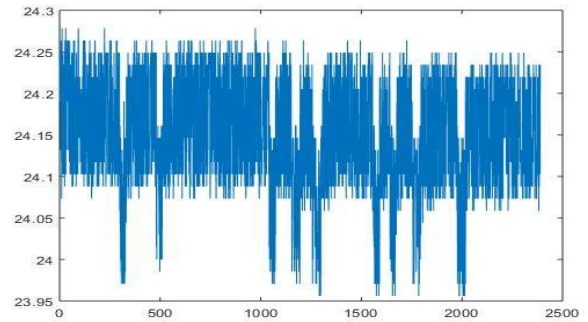


Fig. 2. Sinal original.




Fig. 3. Sinal suavizado.

A etapa seguinte consiste na confecção de uma matriz que agrega em setores o conjunto de valores que compõe o sinal. A intensidade de cada valor define a qual linha ele pertence enquanto o índice a qual coluna. A Fig. 4 apresenta o aspecto do sinal da Fig. 3 na matriz de zeros.

0	0	28	48	159	159	96	37	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
157	138	52	68	0	0	0	0	0	0	0	0	0	58	163
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	64	0	0	0	6	0	100	124	0	104	93	101	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	21	15	43	0	0	17	111	1	9	128	5	14	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	40	11	19	0	28	50	52	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	39	26	3	0	0	0	0

Fig. 4. Representação matricial do sinal

A matriz quadrada da Fig. 4 possui 15 linhas e colunas. Essa quantidade foi selecionada empiricamente após diversos experimentos com matrizes quadradas de 5 até 21 linhas e colunas.

Os vetores utilizados possuíam 478 ou 2398 elementos que demonstraram boa dispersão ao longo da matriz. É essa dispersão que cria os fatores necessários para melhor extração das características do sinal em etapas posteriores. Portanto, a seleção do tamanho da matriz deve ser equilibrado de forma a não ser pequeno demais, o que condensa muitos pontos numa mesma célula e perde-se características importantes ou muito grande, a ponto de se obter muitas células com zero, o que

dificulta a interpretação e aumenta o tempo necessário de processamento.

Após suavizados, os valores necessitam ser normalizados para o intervalo $[0,1]$. A técnica utilizada foi a representada em (6), onde S representa o conjunto de todos os elementos do sinal suavizado em (5).

$$f(x) = \frac{(x-\min(S))}{(\max(S)-\min(S))} \quad \forall x \in S \quad (6)$$

As células da matriz armazenam a quantidade de pontos que existem entre o intervalo de valores de intensidade que as margens superiores e inferiores de cada linha representam e pelo intervalo de tempo ou índice representados pela margem esquerda e direita de cada coluna. Os intervalos são definidos segundo (7).

$$\delta_L = \frac{1}{d}, \quad d > 0 \quad e \quad \delta_C = \frac{b}{d}, \quad d > 0 \quad (7)$$

Sendo d o tamanho da matriz quadrada, δ_L o valor de intervalo de intensidade representado pelas linhas, b o total de elementos do conjunto S e δ_C o valor de intervalo de índices representado pelas colunas, a partir de então, cada elemento $y_{m,n}$ da matriz $Y_{d,d}$ tem seu valor atualizado de acordo com (8), de modo que m e n indicam respectivamente o índice da linha e o da coluna.

$$y_{m,n} = \sum_{i=1}^d \sum_{j=1}^b s_j \cdot \begin{cases} (m-1)\delta_L < s_j \leq m\delta_L \\ (n-1)\delta_C < j \leq n\delta_C \end{cases} \quad (8)$$

A matriz preenchida fica conforme apresentado na Fig. 4, onde é possível notar uma variada quantidade de elementos com valor zero. O valor dos elementos diferentes de zero não é relevante para as falhas degrau e linear uma vez que esses formatos serão analisados através dos perfis que os zeros formam na matriz.

O método inicial aplicado para diferenciar os formatos de interesse consiste na contagem de elementos consecutivos com valor zero até encontrar o primeiro elemento com valor não zero. Isso é feito em ambos os lados de todas as linhas, ou seja, na esquerda da linha, a contagem é feita da primeira coluna em direção a última, enquanto na direita, a contagem é feita da última coluna em direção a primeira. Os valores são armazenados em uma matriz $Z_{d,2}$ através de (9) e (10).

$$z_{m,1} = \sum_{i=1}^f x \cdot \begin{cases} f = d, y_{m,i} = 0 \\ f = i, y_{m,i} \neq 0 \\ x = 1, y_{m,i} = 0 \\ x = 0, y_{m,i} \neq 0 \end{cases} \quad (9)$$

$$z_{m,2} = \sum_{i=1}^f x \cdot \begin{cases} f = d, y_{m,d+1-i} = 0 \\ f = i, y_{m,d+1-i} \neq 0 \\ x = 1, y_{m,d+1-i} = 0 \\ x = 0, y_{m,d+1-i} \neq 0 \end{cases} \quad (10)$$

Em ambas equações, o somatório é interrompido através da atualização do índice de parada quando um valor diferente de zero é encontrado.

A matriz Z é utilizada neste trabalho para extração das características do formato de sinal em degrau ou linear. Contudo, ambas as matrizes, Y e Z , fornecem inúmeras possibilidades de acordo com o perfil a ser buscado.

Por meio da matriz Z , duas outras matrizes são geradas. A primeira $G_{2,4}$ com valores de base e altura do maior retângulo possível de ser formado com os zeros. Esses valores se referem a cada um dos 4 cantos de Y . Nesse mesmo sentido, a segunda matriz $T_{2,4}$ fornece o valor de decaimento horizontal e vertical dos zeros nesses cantos. A análise e comparação dos valores obtidos em G e T permite definir entre quatro possíveis perfis: degrau, linear, ambos e nem um nem outro.

Os valores de G e T são calculados por (11) e (12) respectivamente.

$$A = \{z_{1,1}, \min(z_{1,1}, z_{2,1}), \dots, \min(z_{1,1}, \dots, z_{i,1}), i = 2, \dots, d$$

$$f(x) = a_x \times x \mid a_x \in A, x = 1, \dots, d$$

$$g_{1,1} = \max(f(x) \mid x = 1, \dots, d)$$

$$g_{1,2} = \arg \max_x (f(x) \mid x = 1, \dots, d) \quad (11)$$

$$t_{1,1} = \sum_{i=2}^d x \cdot \begin{cases} x = 1, z_{i,1} < z_{i-1,1} \\ x = 0, z_{i,1} \geq z_{i-1,1} \end{cases}$$

$$t_{1,2} = \sum_{i=2}^d x \cdot \begin{cases} x = z_{i,1} - z_{i-1,1}, z_{i,1} < z_{i-1,1} \\ x = 0, z_{i,1} \geq z_{i-1,1} \end{cases} \quad (12)$$

As proporções dos retângulos e triângulos são então comparadas de acordo com a diagonal que formam entre si na matriz. Se não houver triângulos ou retângulos em ambos os cantos de uma mesma diagonal, nenhum dos dois perfis analisados é atribuído. Caso a dimensão dos triângulos em ambos os lados for superior à dos retângulos, o perfil é considerado linear. Se isso ocorre em apenas uns dos lados, o perfil é linear e degrau e, por fim, degrau se a proporção dos retângulos em ambos os lados for superior à dos triângulos.




Fig. 5. Aspecto da matriz na ocorrência de perfil linear.




Fig. 6. Aspecto da matriz na ocorrência de perfil degrau.




Fig. 7. Aspecto da matriz na ocorrência de perfil intermitente.

A intermitência do sinal é analisada diretamente na matriz Y . O método utilizado para o conjunto de sinais estudados consiste em verificar se as 3 primeiras ou 3 últimas linhas concentram mais de 60% de todos os pontos distribuídos e possuem o primeiro e último quinto das colunas com algum elemento maior que zero. O perfil da intermitência analisado ocorre apenas em um sentido, ou seja, sempre acima ou abaixo da média.

As 3 figuras anteriores apresentam sinais com os formatos bem acentuados e definidos, o que de fato abordagens mais diretas, como por exemplo regressão linear no caso da Fig. , são capazes de identificar. Um sinal mais complexo é apresentado a seguir. A complexidade é atribuída ao fato de o sinal aparentar possuir dois padrões simultâneos, criando áreas de incertezas.




Fig. 8. Sinal original com interpretação complexa.




Fig. 9. Interpretação do sinal através da Matriz de Zeros.

Este sinal visualmente apresenta dois padrões lineares e um degrau. A matriz foi ajustada para um modelo que faça distinção apenas de um perfil. Caso fosse de interesse, outros ajustes permitiriam até mesmo que esse formato fosse considerado como um perfil diferente a ser classificado. No entanto, para o método da Matriz de Zeros, classificá-lo como degrau foi bastante assertivo. Um fato importante é que essa variação ocorre em uma escala muito pequena em comparação com as falhas das Fig. , Fig. e Fig. . Destarte, também é

possível demonstrar o potencial do método em auxiliar na detecção de falhas incipientes.

III. ESTUDO DE CASO

O conjunto de dados utilizado para este trabalho foi obtido da Segunda Competição Internacional de Diagnóstico (DXC'10) [6]. Junto com os dados, foram fornecidos: os tipos de falhas a serem identificadas; conjunto de dados de treinamento, planta esquemática do sistema, tabelas com todos os modos de falha e um conjunto de características que deverão ser informadas de acordo com o tipo de falha detectada. O aspecto geral do sistema é visualizado na Fig. 0.




Fig. 10. Planta do sistema.

São utilizados 11 sensores que direta ou indiretamente permitem avaliar o estado do funcionamento dos componentes do sistema.

Todas as leituras desses sensores foram colocadas em 39 tabelas de treinamento. Cada uma com 240 segundos linearmente espaçadas. Outras 39 tabelas aplicadas na avaliação da competição foram utilizadas para validação do método.

O algoritmo deve identificar as características das falhas de acordo com os padrões demonstrado na Fig. 1. Os limiares não são pré-definidos, portanto sabe-se apenas que em relação a um valor P_n inicial poderão ocorrer variações ΔP em função de possíveis falhas. Essas variações provocarão alterações no perfil do sinal de forma que, quando colocadas em um gráfico, é possível observar um dos seguintes formatos no sinal: linear, degrau ou intermitente.

Desta forma, nenhuma variação por menor que seja pode ser desconsiderada, pois os limiares não são conhecidos e não é possível estabelecer o que se considera um limite de operação sem falhas sem realizar a identificação desses perfis. Isso também faz com que o método seja capaz de detectar falhas mesmo incipientes no sistema.

Seguindo a proposta da competição, este trabalho se dedicou ao estudo da ocorrência de um perfil por vez entre os três possíveis para um único conjunto de dados.

IV. RESULTADOS

Para avaliar criticamente a capacidade de extração de características do sinal, detecção e isolamento de falhas, comparou-se o método MB proposto, denominado Matriz de Zeros, com o método DD denominado Support Vector Machine (SVM). Esta abordagem foi usada como base de comparação, pois apresentou melhores resultados em relação a outros métodos DD, conforme descrito em [7] e em [8].

A descrição sobre o funcionamento do SVM é abordada nesses trabalhos. No entanto, todos os ajustes e configurações aplicados seguiram as utilizadas em [9] devido tanto a taxa de acertos obtida como também na utilização de características do sinal aplicáveis neste trabalho como: média aritmética, erro padrão, variância, curtose, assimetria, valor mínimo, valor máximo, desvio padrão, tamanho do conjunto de sinais, moda e mediana.

Antes da avaliação comparativa entre os métodos, o classificador SVM foi treinado com 39 amostragens disponibilizadas para treinamento utilizando 8 sensores. Três sensores não foram avaliados devido aos dados de treinamento não apresentarem uma quantidade significativa de falhas sobre eles e, nessas condições, o SVM deixaria de ser um método apropriado para esse experimento.

Quanto ao método da Matriz de Zeros, os dados não são usados como treinamento, mas sim como ajuste dos parâmetros do modelo seguido por cada sensor, o que permite a otimização dos parâmetros em (11) e (12).

A validação de ambos foi feita sobre 39 amostras do sinal utilizadas na competição para comparar os resultados entre algoritmos.

A Tabela I apresenta os conceitos utilizados na métrica para comparação dos algoritmos.

TABELA I. DEFINIÇÃO DE TERMOS

<i>Matriz de Confusão</i>	<i>Falha Ocorreu</i>	<i>Falha NÃO Ocorreu</i>
Detectado	Verdadeiro Positivo (VP)	Falso Positivo (FP)
Não Detectado	Falso Negativo (FN)	Verdadeiro Negativo (VN)

$$ACU = \frac{(VP+VN)}{(VP+VN+FN+FP)} \quad (13)$$

$$TFP = \frac{FP}{(FP+VN)} \quad (14)$$

$$TFN = \frac{FN}{(FN+VP)} \quad (15)$$

ACU é a acurácia do algoritmo, que representa a probabilidade, na saída, de classificar corretamente o conjunto de dados de entrada entre falha e não falha. *TFP* é a taxa de falsos positivos, que representa a probabilidade de classificar erroneamente como falha o conjunto de dados de entrada. E, por último, *TFN* representa a taxa de falsos negativos, ou seja, a probabilidade de classificar erroneamente como não falha o conjunto de dados de entrada.

Os conjuntos de dados que de fato possuem falha e o algoritmo os classifica com perfil diferente do correto são contabilizados como falsos negativos porque não atingem o objeto de classificar corretamente.

As

Fig. 1 e Fig. 12 apresentam os valores absolutos de falhas de cada sensor em relação aos formatos a serem identificados. É possível, dessa forma, analisar em qual formato de sinal e com qual tipo de sensor os algoritmos cometem mais erros. O método proposto utiliza-se desses resultados para ajustar os modelos usados na matriz *Y*.




Fig. 11. Erros de classificação por sensor da Matriz de Zeros.

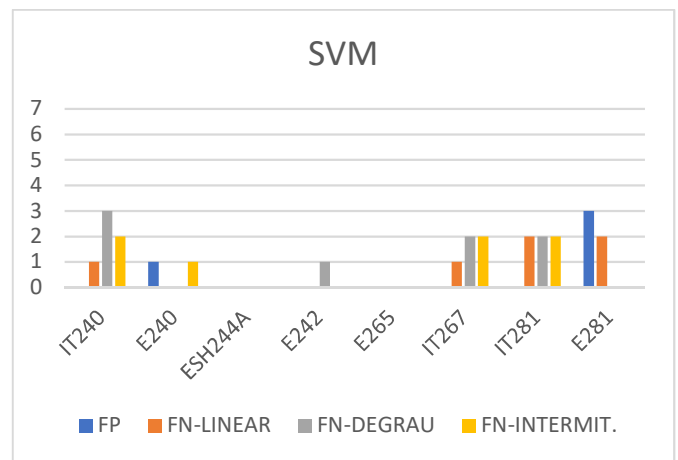


Fig. 12. Erros de classificação por sensor do SVM.

A Fig. 3 compila em valores absolutos os formatos de sinal corretamente detectados para cada método com o total da presença deles nas amostras de validação.

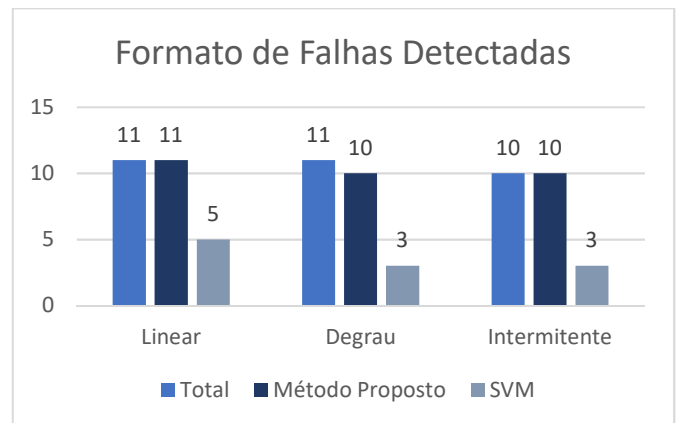


Fig. 13. Total de formatos de falhas identificados por método.

A Tabela II compara os erros e acertos entre os métodos de acordo com a métrica proposta.

TABELA II. COMPARAÇÃO DOS RESULTADOS

	<i>Matriz de Zeros</i>	<i>SVM</i>
VN	441	446
VP	31	11
FN	1	21
FP	10	5
ACU	0,9772 – 97,72%	0,9462 – 94,62%
TFP	0,0222 – 2,22%	0,0111 – 1,11%
TFN	0,0313 – 3,13%	0,6563 – 65,63%

V. CONCLUSÕES E TRABALHOS FUTUROS

Ambos os métodos apresentaram bons resultados, tendo o método proposto apenas sido superado no critério TFP. Porém, o SVM apresentou a TFN muito elevada. Isso ocorre devido a um conjunto de dados de treinamento em quantidade insuficiente para ajuste desse método. A questão se impõe dentro do conjunto de dados disponibilizados no contexto da competição DXC'10.

No entanto, a TFP do SVM reflete a excelente capacidade dessa metodologia em classificar entre falha e não falha [10], sendo os erros de classificação computados como FN, prejudicando sua pontuação nesse quesito.

Ainda assim, as abordagens voltadas para dados (Data-Driven) podem ser bastante eficazes mesmo em um conjunto de treinamento como o utilizado, basta que o conjunto seja capaz de replicar os formatos de falhas esperados. Portanto, mais importante que o tamanho do conjunto de treinamento, é certificar sua representatividade em relação ao conjunto de falhas esperado. Na análise em questão, essa percepção somente foi possível durante o processo final de validação.

O método proposto conseguiu resultados considerados bastante satisfatórios. O método se baseia no modelo do sinal emitido pelo sensor, ou seja, ao invés de trabalhar com o modelo do sistema como um todo, ele trabalha com o modelo do sensor, adequando-se a natureza do formato do sinal por ele emitido. As etapas utilizadas incorporam o modelo do sinal na matriz proposta, permitindo que o método seja aplicado em um conjunto de sensores de mesmas características independente dos dados de treinamento.

O ponto fraco desse método reside na necessidade de ou uma compreensão prévia do funcionamento do sensor ou de um conjunto de dados que permita entender as características do funcionamento dele para que os modelos de formato de sinal sejam bem representativos. Porém, diferente da abordagem *Data-Driven*, não há aprendizagem por parte do método, cabe a quem implementá-lo ajustar os parâmetros. É uma questão inerente às abordagens *Model-Based*.

Como sugestão de trabalhos futuros, há uma variedade de sinais e formatos que não foram explorados com a utilização da matriz. Há também a possibilidade de compará-lo com outros métodos DD.

Por fim, a novidade e originalidade desse trabalho pode ser observada na abordagem de um novo método orientado ao modelo, para extração de características dos sinais para diagnóstico e isolamento de falhas em um ambiente onde o modelo do sistema não é conhecido e o conjunto de dados é

limitado em representar o universo de falhas que se almeja detectar.

REFERÊNCIAS

- [1] D. Jung, K. Y. Ng, E. Frisk, and M. Krysander, "Combining model-based diagnosis and data-driven anomaly classifiers for fault isolation," *Control Eng. Pract.*, vol. 80, no. September, pp. 146–156, 2018.
- [2] S. X. Ding, *Model-Based Fault Diagnosis Techniques*, Second Edi. London: Springer London, 2013.
- [3] H. Khorasgani, D. Jung, and G. Biswas, "Structural approach for distributed fault detection and isolation," *IFAC-PapersOnLine*, vol. 28, no. 21, pp. 72–77, 2015.
- [4] S. Rawat and S. Rawat, "Multi-sensor data fusion by a hybrid methodology - A comparative study," *Comput. Ind.*, vol. 75, pp. 27–34, 2016.
- [5] M. Danancher, M. Roth, J. J. Lesage, and L. Litz, "A comparative study of three model-based FDI approaches for Discrete Event Systems," 2011 3rd Int. Work. Dependable Control Discret. Syst. DCDS'11 - Conf. Proc., pp. 29–34, 2011.
- [6] S. Poll, J. De Kleer, A. Feldman, D. Garcia, and S. Narasimhan, "Second International Diagnostic Competition – DXC ' 10," pp. 1–15, 2010.
- [7] H. M. Castilho, "Aircraft Bleed Valve Fault Classification using Support Vector Machines and Classification Trees," 2018.
- [8] M. Jung, O. Niculita, and Z. Skaf, "Comparison of Different Classification Algorithms for Fault Detection and Fault Isolation in Complex Systems," *Procedia Manuf.*, vol. 19, no. 2017, pp. 111–118, 2018.
- [9] R. Jegadeeshwaran and V. Sugumaran, "Fault diagnosis of automobile hydraulic brake system using statistical features and support vector machines," *Mech. Syst. Signal Process.*, vol. 52–53, no. 1, pp. 436–446, 2015.
- [10] H. A. Nozari, S. Nazeri, H. D. Banadaki, and P. Castaldi, "Model-free fault detection and isolation of a benchmark process control system based on multiple classifiers techniques—A comparative study," *Control Eng. Pract.*, vol. 73, no. June 2017, pp. 134–148, 2018.